

SVEUČILIŠTE U ZAGREBU ŠUMARSKI FAKULTET
ŠUMARSKI ODSJEK
SVEUČILIŠNI DIPLOMSKI STUDIJ
URBANO ŠUMARSTVO, ZAŠTITA PRIRODE I OKOLIŠA

KATARINA MILANOVIĆ

OBRADA I ANALIZA 3D PODATAKA IZ
AEROFOTOGRAMETRIJSKOG SNIMANJA

DIPLOMSKI RAD

ZAGREB, 2018.

ŠUMARSKI FAKULTET SVEUČILIŠTA U ZAGREBU
ŠUMARSKI ODSJEK

OBRADA I ANALIZA 3D PODATAKA IZ
AEROFOTOGRAMETRIJSKOG SNIMANJA

DIPLOMSKI RAD

Diplomski studij: Urbano šumarstvo, zaštita prirode i okoliša

Predmet: Analiza i valorizacija prostora

Ispitno povjerenstvo:

1. Izv. prof. dr. sc. Ante Seletković
2. Prof. dr. sc. Renata Pernar
3. Dr. sc. Jelena Kolić

Student: Katarina Milanović

JMBAG: 0068218759


Broj indeksa: 812/16

Datum odobrenja teme: 20.04.2018.

Datum predaje rada: 20.09.2018.

Datum obrane rada: 21.09.2018.

Zagreb, 2018.

	IZJAVA O IZVORNOSTI RADA	OB ŠF 05 07
		Revizija: 1
		Datum: 28.6.2017.

„Izjavljujem da je moj *diplomski rad* izvorni rezultat mogega rada te da se u izradi istoga nisam *koristila* drugim izvorima osim onih koji su u njemu navedeni“.

vlastoručni potpis

Katarina Milanović

U Zagrebu, 20. 09. 2018.

Dokumentacijska kartica

Naslov	Obrada i analiza 3D podataka iz aerofotogrametrijskog snimanja
Title	Processing and analysis of 3D data from aerial images
Autor	Katarina Milanović
Adresa autora	Norinska 64, Metković
Mjesto izrade	Zagreb
Vrsta objave	Diplomski rad
Mentor	Izv. prof. dr. sc. Ante Seletković
Izradu rada pomogao	Doc. dr. sc. Mario Ančić
Godina objave	2018.
Obujam	33 str., 20 slika + 50 navoda literature
Ključne riječi	3D oblak točaka, aerofotogrametrijsko snimanje, daljinska istraživanja, stereoskopske snimke, urbane šume
Key words	3D point cloud, aero – photogrammetric surveys, remote sensing, stereoscopic shots, urban forests
Sažetak	<p>Stalni napredak i poboljšanje kvalitete snimaka, razvoj naprednih algoritama obrade aerosnimaka, poboljšanje snage i kapaciteta računala, pružaju još veće mogućnosti njihove upotrebe pri izmjeri šuma. U ovom diplomskom radu prikazati će se cjelokupni postupak obrade kao i analize 3D podataka dobivenih iz aerofotogrametrijskog snimanja područja Grada Zagreba, kao i izrada DTM i DSM osnovnih derivata iz stereoskopskog aerosnimanja. Za područje istraživanja određen je Grad Zagreb, konkretno Park Ribnjak, Trg kralja Petra Svačića i Trg kralja Tomislava. Za fotogrametrijsku izmjeru korištene su digitalne kolorne i infracrvene kolorne (ICK) stereo aerosnimke iz 2012. godine, te trodimenzionalni (3D) vektorski podaci na temelju kojih je izrađen digitalni model reljefa (DMR). U diplomskom radu su prikazane mogućnosti primjene 3D podataka iz aerofotogrametrijskog snimanja za potrebe praćenja i inventure urbanih područja. Glavni produkti dobiveni aerofotogrametrijskim snimanjem su izrađen DMT - digitalni model terena i DMP – digitalni model površina, koji nam omogućuju na brz i efikasan način prikupljanje podataka o visini, širini krošnje, površini krošnje pojedinačnog stabla. Na temelju obrađenih aerofotogrametrijskih snimaka područja istraživanja razvidno je da nam svi dobiveni produkti (3d oblaci točaka, DMT i DMP) omogućuju izmjera samo gornje etaže unutar neke sklopljene sastojine ili šume, ali za potrebe praćenja stanja stabala i vegetacije urbanih područja daje korisne i vrlo precizne podatke. Rezultati ovog istraživanja ukazuju na neke od mogućnosti upotrebe 3D podataka dobivenih metodama</p>

	daljinskih istraživanja, te otvaraju nove mogućnosti u analizama i interpretaciji funkcija urbanih šuma i parkova.
Summary	<p>Continuous progress and improving of images quality, development of advanced algorithms for aerospace processing, improving of power and PC capabilities, provide even greater opportunities for their use in forest measurements. In this graduate thesis will be presented the entire processing procedure as well as the analysis of 3D data obtained from the aero-photogrammetric surveying of the City of Zagreb, as well as the production of DTM and DSM basic stereoscopic aerosol derivatives. As the area of research, was defined the City of Zagreb, specifically Park Ribnjak, Trg kralja Petra Svačića and Trg kralja Tomislava. For photogrammetric measurements were used the digital color and infrared color (ICK) stereo aerial images from 2012, and three-dimensional (3D) vector data, based on which a digital relief model (DMR) was developed. The graduate thesis presents the possibilities of using 3D data from aero - photogrammetric surveys for the purposes of monitoring and inventory of urban areas. The aerial photography obtained the DMT - digital terrain model and DMP – digital surface model, which enable us to collect data of tree heights on a fast and efficient way, as well as the width of the crown and the surface of the crown of an individual tree. Based on the aero-photogrammetric surveys of the field of investigation, it is clear that all the products obtained (3D point clouds, DMTs and DMPs) allow only the upper floors to be surveyed within an assembled stand or forest, but for the purposes of monitoring the tree condition and urban vegetation it gives us useful and very precise files. The results of this research are pointing to some of the possible uses of 3D data obtained by remote sensing methods and open up new possibilities in analyzing and interpreting the functions of urban forests and parks.</p>

***"Nema lepšeg zadatka nego omogućiti nekom razvitak i pomoći čovjeku u njegovoj težnji
za usponom."***

- Ivo Andrić

Zahvaljujem se, prije svega, svom mentoru izv. prof. dr. sc. Anti Seletkoviću te doc. dr. sc. Mariu Ančiću koji su mi svojim znanjem, savjetima te ustupanjem potrebnih materijala pomogli pri izradi ovoga diplomskog rada. Veliko hvala i kolegi Tediju Srdoču koji je u svemu sudjelovao i pomogao.

Također, zahvaljujem se svim svojim prijateljima i prijateljicama, koji su uvijek bili uz mene.

Posebno hvala mojoj obitelji, prije svega mojim sestrama koje su oduvijek bile moja nit vodilja i moralna podrška. Hvala i mojoj najdražoj nećakinji koja je bila najslađa potpora u svemu!

Na kraju, najveću zahvalu zaslužuju moji roditelji, koji su uvijek bili tu uz mene, bez obzira na sve i bez kojih danas ne bih bila ovo što jesam.

Veliko hvala svima!

SADRŽAJ

1.	UVOD	1
1.1.	Aerofotogrametrijsko snimanje	3
1.2.	Digitalni model površine	5
2.	CILJ ISTRAŽIVANJA	8
3.	MATERIJALI I METODE RADA	9
3.1.	Područje istraživanja.....	9
3.1.1.	Park Ribnjak.....	10
3.1.2.	Trg kralja Petra Svačića	11
3.1.3.	Trg kralja Tomislava	13
3.2.	Fotogrametrijski materijal	14
3.3.	Izrada digitalnih modela površine	15
4.	REZULTATI ISTRAŽIVANJA	17
5.	ZAKLJUČCI	25
6.	LITERATURA.....	26

1. UVOD

Metode daljinskih istraživanja danas predstavljaju jedan od najvažnijih načina prikupljanja prostornih podataka u mnogim djelatnostima, a njihova primjena u šumarstvu prvenstveno ima za cilj unaprijediti postojeće operative metode prikupljanja podataka u inventuri šuma. Jedna od najstarijih te ujedno i najčešće korištenih metoda daljinskih istraživanja u šumarstvu jest vizualna (manualna) interpretacija odnosno stereo fotogrametrijska izmjera aerosnimaka. Mogućnost procjene varijabli pojedinačnih stabala te strukturnih elemenata šumskih sastojina fotogrametrijskom izmjerom na stereoparovima klasičnih analognih aerosnimaka primjenom analognih ili analitičkih stereoinstrumenata (tzv. analogna i analitička fotogrametrija) proučavali su brojni autori (npr. Ståhl 1992, Benko 1993, Næsset 1996, Kovats 1997, Anttila 1998, Eid i dr. 2004, Magnusson i Fransson 2005). Budući da su provedena istraživanja u pojedinim slučajevima (npr. jednodobne sastojine, kulture) pokazala zadovoljavajuće rezultate, aerosnimke su u većoj ili manjoj mjeri postale sastavnim dijelom inventure šuma u pojedinim zemljama (npr. Finska, Švedska, Švicarska, Kanada) bilo na lokalnoj (uređajna inventura) ili regionalnoj odnosno nacionalnoj razini (nacionalna inventura šuma) (Næsset 2002, Magnusson i dr. 2007, Tuominen i dr. 2014, Ginzler i Hobi 2015). Međutim, u većini drugih zemalja pa tako i Hrvatskoj, aerosnimke nisu našle širu praktičnu primjenu pa se inventure šuma u tim slučajevima baziraju isključivo na klasičnoj terenskoj izmjeri. Razlozi tome bili su višestruki: visoka cijena opreme i aerosnimaka, zahtijevan uredski rad koji iziskuju klasične fotogrametrijske metode, nedovoljno stručnih kadrova, ali i dobiveni rezultati koji često nisu udovoljavali svim potrebama prakse (Kušan 1996, Balenović i dr. 2010).

U međuvremenu, razvoj računalne tehnologije 80-tih i 90-tih godina prošlog stoljeća potaknuo je snažan razvoj metoda i tehnika daljinskih istraživanja. Tako je i fotogrametrija, u

posljednjih tridesetak godina, prošla razvojni put od analogne, preko analitičke do digitalne fotogrametrije, tijekom kojeg su analogne aerosnimke, te analogni i analitički stereoinstrumenti zamijenjeni digitalnim aerosnimkama te digitalnim fotogrametrijskim stanicama (Magnusson i dr. 2007, Linder 2009). Pri tome su ključnu ulogu u razvoju iz analitičke u digitalnu fotogrametriju imali pojava digitalne fotogrametrijske stanice (DFS) krajem 1980-tih godina, te digitalnih aerofotogrametrijskih kamera 2000-tih godina (Petrie i Walker 2007). Nakon toga slijedio je njihov kontinuirani razvitak, tako da današnje digitalne aerofotogrametrijske kamere omogućuju pridobivanje digitalnih aerosnimaka vrlo visokih prostornih i radiometrijskih rezolucija (Sandau 2010). Primjenom digitalnih aerosnimaka u kombinaciji s digitalnim fotogrametrijskom stanicom te raznim algoritmima za digitalnu obradu aerosnimaka, niz zahtjevnih fotogrametrijskih procesa (npr. aerotriangulacija, digitalno modeliranje terena, izrada digitalnog ortofota) je manje ili više automatizirano, a rukovanje aerosnimkama znatno olakšano.

Primjenom digitalnih aerosnimaka i DFS, informacije o pojedinačnim stablima i šumskim sastojinama mogu se dobiti analognim (manualnim) ili automatiziranim postupcima interpretacije (izmjere) (Gong i dr. 2002, Korpela 2004). Uslijed određenih nedostataka analognih metoda (veći angažman stručne radne snage - interpretatora, veći utrošak vremena, subjektivnost interpretatora), automatizirane metode u posljednje vrijeme zauzimaju znatno veće zanimanje istraživača. Rezultati provedenih istraživanja ukazuju na veliki potencijal automatiziranih metoda pri procjeni strukturnih elemenata sastojina na razini plohe ili čitave sastojine (Ota i dr. 2015, White i dr. 2015, Yu i dr. 2015). Međutim, za točnu interpretaciju pojedinačnih stabala (npr. lokacija, vrsta drveća) automatizirane metode još uvijek ne mogu u potpunosti zamijeniti analogne, te je stoga njihova praktična primjena još uvijek upitna, naročito u mješovitim, gustim sastojinama (Smits i dr. 2012). Vizualnom interpretacijom odnosno klasičnom fotogrametrijskom izmjerom u stereomodelu, dio elemenata pojedinačnih

stabala i šumskih sastojina moguće je direktno mjeriti, procjenjivati ili interpretirati na digitalnim aerosnimkama (vrsta drveća, broj stabala, visina stabala i sastojina, dimenzije krošnje, sklop), dok se drugi dio elemenata dobiva indirektno na temelju uspostavljenih odnosa (modela) između fotogrametrijski izmjerenih veličina (prsni promjer, temeljnica, volumen).

U Hrvatskoj su u posljednjih nekoliko godina provedena određena istraživanja o mogućnostima primjene digitalnih aerosnimaka u inventuri šuma. Istraživana je njihova primjena u izlučivanju sastojina (Balenović i dr. 2012), za procjenu aritmetički srednjeg sastojinskog promjera (Balenović i dr. 2013) i aritmetički srednje sastojinske visine (Balenović i dr. 2015), te za procjenu zdravstvenog stanja stabala (Kolić i dr. 2015). U svim navedenim istraživanjima korištene su metode klasične fotogrametrijske izmjere i vizualne interpretacije digitalnih aerosnimaka na DFS te su dobiveni rezultati ukazali na veliki potencijal njihove praktične primjene. U ovom diplomskom će se prikazati neke mogućnosti primjene 3D podataka iz aerofotogrametrijskog snimanja za potrebe urbanog šumarstva.

1.1. Aerofotogrametrijsko snimanje

Aerosnimak je, kako i sam naziv kaže, fotografija dijela površine Zemlje ili drugoga nebeskoga tijela načinjena iz zrakoplova ili svemirske letjelice. Svoju su primjenu aerosnimke našle u disciplinama kao što su daljinska istraživanja te u sklopu njih fotogrametriji. Fotogrametrija je tehničko-znanstvena disciplina i metoda prikupljanja podataka sa distance, korištenjem fotografskih snimaka iz zraka ("Fotogrametrija i daljinska istraživanja", 2018). Daljinska istraživanja opisuju metodu prikupljanja informacija o nekom objektu pomoću uređaja za snimanje ili istraživanje koji je bežičan i nije u fizičkom ili bliskom kontaktu s objektom snimanja. Takvim snimanjima mogu se dobiti geomorfološke, geološke, pedološke,

šumarske, hidrološke, arheološke i druge osobine promatranih objekata ("Fotogrametrija i daljinska istraživanja", 2018). Aerosnimke, u sklopu aerofotogrametrijskog snimanja, u posljednje vrijeme dobivaju sve više na značenju u području šumarstva i urbanoga šumarstva, kako u svijetu, tako i u Hrvatskoj. Aerofotogrametrijsko snimanje i daljinska istraživanja (radarsko i lasersko snimanje) koriste se za prikupljanje točnih topografskih podataka visoke rezolucije. Korištenjem konvencionalnih i digitalnih aero- i satelitskih snimaka u sklopu fotogrametrijskih metoda, omogućava se prikupljanje podataka koje u konačnici služi za izradu digitalnog modela terena (DMT). DMT obuhvaća visine, interpolacijsku funkciju te ostale elemente oblikovanja reljefa (pr. bridovi, karakteristične točke i sl.). Na temelju informacija dobivenih obradom DMT-a omogućeno je adekvatno upravljanje prostornim resursima, u ovom slučaju šumskom vegetacijom na području gradova ili izvan njih.

Uz gospodarske šume u kojima je primjena aerofotogrametrije potrebna u svrhu izrade osnova ili planova gospodarenja, Balenović i sur. (2010) navode kako je jedno od područja gdje se ponajprije može očekivati primjena aerosnimaka u uređivanju šuma u Hrvatskoj područje privatnih šuma, za koja još ne postoje programi gospodarenja. U novije vrijeme, zahvaljujući sve većoj osviještenosti ljudi za prostor u kojemu se nalaze, kao i stalnom napretku te poboljšanju kvalitete snimaka, razvoja naprednih algoritama obrade aerosnimaka, poboljšanja kapaciteta i snage računala (Leberl i dr. 2010), pružaju se još veće mogućnosti njihove upotrebe u izmjeri šuma u urbanim sredinama ili izvan njih. Stabla u urbanim sredinama imaju mnoge prednosti kao što su očuvanje energije, poboljšanje kvalitete vode, minimaliziranje utjecaja stakleničkih plinova i brojnih drugih zagađivača okoliša te povezivanja urbanih stanovnika s prirodom (Dogon-Yaro 2016, citirano prema McPherson 2006, Nowak D. J. 2007). Kartiranje stabala stoga ima važnu ulogu u modernom upravljanju urbanim prostornim podacima, budući da se brojne prednosti i primjene koje su potrebne za daljnje upravljanje, nasljeđuju upravo iz takvih detaljno ažuriranih izvora podataka (Dogon-

Yaro 2016). Pravovremeno i precizno prikupljanje informacija o stanju urbanih stabala služi kao alat potreban za bolje razumijevanje urbanih ekosustava i njihovih brojnih vrijednosti koje su ključne za izgradnju strategije održivog razvoja (Dogon-Yaro 2016).

1.2. Digitalni model površine

Digitalni model površine (DSM, prema engl. Digital Surface Model) predstavlja matematički model Zemljine površine, uključujući izgrađene objekte i vegetaciju (Paparoditis i Polidori 2002). Ukoliko se radi o DSM-u nekog šumskog područja, on predstavlja gornju površinu krošanja. Za izradu DSM-a uglavnom se koriste podaci dobiveni metodama daljinskih istraživanja. Između različitih metoda daljinskih istraživanja, posljednjih desetak godina zračno lasersko skeniranje (LiDAR, prema engl. Light Detection and Ranging) i digitalna stereofotogrametrija pokazale su se najpouzdanijim metodama izrade DSM-a (Höhle i Höhle 2009). Pri tome su kod LiDAR-a glavni ograničavajući čimbenici visoki troškovi snimanja, naročito kada se radi o većim područjima istraživanja i opetovanim snimanjima. S druge strane, troškovi aerosnimanja znatno su niži od LiDAR-a te se u mnogim zemljama, uključujući i Hrvatsku, aerosnimke redovno ažuriraju kroz periodička aerosnimanja svakih nekoliko godina za topografske svrhe (Nurminen i dr. 2013). Nedavni napredak i poboljšanje kvalitete aerosnimaka (radiometrijska i geometrijska rezolucija), razvoj naprednih algoritama obrade aerosnimaka, poboljšanje kapaciteta i snage računala (Leberl i dr. 2010), potaknuo je brojna istraživanja o mogućnosti korištenja DSM-a dobivenog digitalnom stereofotogrametrijom iz aerosnimaka u mnogim djelatnostima, pa tako i u šumarstvu (Bohlin i dr. 2012, Järnstedt i dr. 2012, Nurminen i dr. 2013, Straub i dr. 2013, Pitt i dr. 2014, Gobakken i dr. 2015, Granholm i dr. 2015, Stepper i dr. 2015, Rahlf i dr. 2015, St-Onge i dr. 2015, Puliti i dr. 2016, Tanhuanpää i dr. 2016).

Postupak izrade DSM-a u digitalnoj fotogrametriji bazira se na principu automatiziranog stereofotogrametrijskog procesiranja aerosnimaka. Termini koji se koriste za opis postupka su 'slikovna korelacija' (engl. image correlation), 'digitalna korelacija aerosnimaka' (engl. correlation of digital images), odnosno 'usklađivanje snimaka' (engl. image matching). Cilj slikovne korelacije je automatsko određivanje slikovnih koordinata korespondirajućih točaka (piksela) lijeve i desne aerosnimke (stereopara) na temelju njihove radiometrijske i geometrijske sličnosti (White i dr. 2013). Ukoliko je korelacija zadovoljavajuća (npr. koeficijent korelacije za promatranu točku lijeve i desne aerosnimke veći od unaprijed postavljenog donjeg praga), točka se uzima u obzir za daljnju obradu (aerotriangulacija, digitalno modeliranje terena, itd.). Rezultat slikovne korelacije je trodimenzionalni oblak točaka (engl. image point cloud) koji se u daljnjim postupcima (interpolacijom) može koristiti za modeliranje terena, i to ponajprije za izradu DSM-a. DSM dobiven slikovnom korelacijom aerosnimaka vrlo je sličan onome koji se dobije iz prvog povratnog impulsa zračnim laserskim skeniranjem (Pitt i dr. 2014).

U šumarstvu, DSM se uglavnom koristi u kombinaciji s digitalnim modelom reljefa (DTM, prema engl. Digital Terrain Model) dobivenim iz aerosnimaka fotogrametrijskim putem (npr. u Hrvatskoj fotogrametrijskom izmjerom lomnih linija terena i izmjerom pravokutne mreže visinskih točaka) ili u novije vrijeme iz LiDAR podataka. Preklapanjem DTM-a i DSM-a, odnosno oduzimanjem DTM-a od odgovarajućeg DSM-a dobije se digitalni model visina sastojina ili digitalni model visina krošanja (CHM, prema engl. Canopy Height Model) koji se potom u kombinaciji s referentnim terenskim podacima može koristiti za procjenu različitih varijabli stabala i šumskih sastojina. Nedavna istraživanja ukazala na veliki potencijal za primjenu CHM-a izrađenog iz fotogrametrijskog DSM-a u procjeni glavnih strukturnih elemenata šumskih sastojina (Bohlin i dr. 2012, Järnstedt i dr. 2012, Nurminen i dr. 2013, Straub i dr. 2013, Pitt i dr. 2014, Gobakken i dr. 2015, Granholm i dr. 2015, Stepper i dr.

2015, Rahlf i dr. 2015, St-Onge i dr. 2015, Puliti i dr. 2016, Tanhuanpää i dr. 2016). Pri tome se točnost procijenjenih strukturnih elemenata sastojina razlikuje ovisno o tipu šume i strukturi sastojina u kojima je istraživanje provedeno, o pouzdanosti korištenih modela za procjenu strukturnih elemenata sastojina na temelju podataka dobivenih iz CHM-a, te o samoj kvaliteti i točnosti CHM-a, odnosno DTM-a i DSM-a.

Kvaliteta fotogrametrijskog DSM-a ovisi o korištenom algoritmu, odnosno metodi slikovne korelacije, kvaliteti aerosnimaka (npr. geometrijska, radiometrijska, spektralna rezolucija), karakteristikama aerosnimanja (npr. uzdužni/poprečni preklop, vremenski uvjeti, dnevno vrijeme aerosnimanja, kutu upadanja sunčevih zraka, itd.), te o karakteristikama objekata/vegetacije na aerosnimkama (Baltsavias i dr. 2008, St-Onge i dr. 2008). Budući da je šuma vrlo heterogen sustav, DSM šumskih područja često je slabije kvalitete odnosno manje točnosti nego DSM nekog otvorenog područja (bez objekata i pokrova), s izgrađenim objektima ili travnatom vegetacijom (Hoby i Ginzler 2012, Balenović i dr. 2015, Ginzler i Hoby 2015).

2. CILJ ISTRAŽIVANJA

Stalni napredak i poboljšanje kvalitete snimaka, razvoj naprednih algoritama obrade aerosnimaka, poboljšanje snage i kapaciteta računala, pružaju još veće mogućnosti njihove upotrebe pri izmjeri šuma. U ovom diplomskom radu prikazati će se cjelokupni postupak obrade kao i analize 3D podataka dobivenih iz aerofotogrametrijskog snimanja područja Grada Zagreba, kao i izrada DTM i DSM osnovnih derivata iz stereoskopskog aerosnimanja.

3. MATERIJALI I METODE RADA

3.1. Područje istraživanja

Za područje istraživanja određen je Grad Zagreba, konkretno Park Ribnjak, Trg kralja Petra Svačića i Trg kralja Tomislava. Za fotogrametrijsku izmjeru korištene su digitalne kolorne i infracrvene kolorne (ICK) stereo aerosnimke iz 2012. godine (Slike 1. i 2.) te trodimenzionalni (3D) vektorski podaci na temelju kojih je izrađen digitalni model reljefa (DMR). Fotogrametrijski materijal snimila je i izradila tvrtka Geodetski zavod d.d. Osijek. prema specifikacijama proizvoda Državne geodetske uprave.




Slika 1. i 2. Digitalne kolorne i infracrvene kolorne (ICK) stereo aerosnimke iz 2012. godine

3.1.1. Park Ribnjak

Park Ribnjak jedan od najljepših gradskih parkova. Nalazi se između ulice Ribnjak (na istoku) i zidina zagrebačke Katedrale. Ulica Ribnjak je, iako ne najveća najšira ni najduža (već upravo suprotno), jedna od najvažnijih gradskih ulica koja spaja Donji grad sa Medveščakom, Mihaljevcem i ostalim sjevernim dijelovima Grada. Ribnjak je naziv biskupskog parka istočno od stolne crkve - današnje zagrebačke Katedrale. Na tom mjestu prije je bio umjetni ribnjak, koji je vodu dobivao iz potoka Medveščaka. Kada je ribnjak isušen, lokalitet je uređen i pretvoren u gradski park. Uz istočne zidine Kaptola proteže se park Ribnjak. Ime je dobio po biskupskim ribnjacima, koji su se ovdje nalazili sve do 19. stoljeća. Tada je cijeli prostor pretvoren u perivoj engleskog tipa, s vodopadima, egzotičnim biljkama i ukrasnim kipovima. Park je uređen na poticaj biskupa Alagovića, 1829. godine. Park se danas prostire na gotovo 40.000 četvornih metara površine i u njemu se može vidjeti trideset godina stara tisa, stari primjerak atlaskog cedra, mnoštvo magnolija i likvidambara. Ribnjak se zove i ulica koja se proteže uz istočnu granicu parka.



Slika 3. Park Ribnjak



Slika 4. Položaj Parka Ribnjak

3.1.2. Trg kralja Petra Svačića

Park na Svačićevom trgu (Slika 5.) uređen je 1901. godine prema nacrtu arhitekta Viktora Kovačića. Tridesetih godina je preuređen prema projektu Ćirila Jegliča. U drugom svjetskom ratu dosta je oštećen i 1955. godine Zvonimir Koni uspješno obnavlja Jegličevu zamisao trga te ga vrlo kvalitetno uređuje. Nekad simetrično rješenje parka pretvoreno je u pejzažni park sa dječjim igralištem. Perivojni trg obnavljan je i 1991.godine (Slika 5.) kada su obnovljene staze i dječje igralište. Površina parka je otprilike 0,5 ha i u sklopu je gusto naseljenih blokova.



Slika 5. Park na Trgu kralja Petra Svačića



Slika 6. Trg kralja Petra Svačića

3.1.3. Trg kralja Tomislava

Jedan od najvažnijih simbola grada Zagreba je Trg kralja Tomislava, kojim dominira spomenik prvom hrvatskom kralju, rad kipara Roberta Frangeš-Mihanovića. Trg kralja Tomislava jedan je od onih koji se uklapa u poznatu zelenu odnosno Lenucijevu potkovu. Prije dovršenja imao je samo naziv Trg »L«, jer su se tada trgovi obilježavali slovima, a ulice brojevima. Izgradnjom kolodvora, trg od 1895. nosi ime po caru i kralju Franji Josipu, kako bi nakon raspada Austro-Ugarske ponio ime po prvom hrvatskom kralju.

Trg kralja Tomislava uređen je kao parterni vrt s fontanom i kipom kralja Tomislava. Sa sjeverne strane omeđen je zgradom Umjetničkog paviljona (1897.-98.), a s južne se nalazi Glavni kolodvor. Od zgrada se također ističu kuća slikara Vlahe Bukovca (1895.-96.), te kuća Feller (1903.), djelo arhitekta Vlahe Bukovca u stilu venecijanske neogotike. Isti je arhitekt projektirao i znamenitu secesijsku kuću Kalina (1903.-04.), na uglu Gundulićeve i Masarykove ulice, poznatu po prikazima šišmiša i keramičkim pločicama koje su nastale u tvornici vlasnika kuće Josipa Kalline. Trg kralja Tomislava, popularno zvan Tomislavac, posljednji je park u Istočnom perivoju Lenucijeve potkove (Slika 7.).



Slika 7. Trg kralja Tomislava



Slika 8. Park unutar Trga Kralja Tomislava

3.2. Fotogrametrijski materijal

Za fotogrametrijsku izmjeru korištene su digitalne kolorne i infracrvene kolorne (ICK) stereo aerosnimke, te trodimenzionalni (3D) vektorski podaci na temelju kojih je izrađen digitalni model reljefa (DMR). Fotogrametrijski materijal snimila je i izradila tvrtka Geodetski zavod d.d. Osijek. prema specifikacijama proizvoda Državne geodetske uprave.

Aerotriangulacija je napravljena na fotogrametrijskoj digitalnoj stanici ImageStation 2001. Korišten je program ImageStation Automatic Triangulation.

Multispektralna aerofotogrametrijska snimanja podržana GPS/IMU tehnologijom provedena su digitalnom aerofotogrametrijskom kamerom velikog formata Microsoft UltraCamX (Microsoft, Vexcel Imaging GmbH, Graz, Austrija). Kamera je matričnog tipa, a sastoji od 13 CCD (eng. *Charge Coupled Device*) senzora. Pomoću 9 senzora prikupljaju se informacije u pankromatskom području, dok se preostala 4 senzora koriste za prikupljanje multispektralnih informacija iz plavog (445-515 nm), zelenog (510-590 nm), crvenog (600-680 nm) i blisko infracrvenog (710-830 nm) dijela spektra. Rezolucija kamere je 136 megapiksela, a žarišna duljina objektiva kamere pri snimanju iznosila je 100,5 mm. Detaljan opis tehničkih karakteristika kamere kao i postupka obrade snimaka nakon leta može se naći u radu Gruber i. dr. (2008).

Pomoću GPS/IMU tehnologije korištene tijekom aerosnimanja, svakoj snimci zabilježena je precizna pozicija projekcijskog centra, te parametri vanjske orijentacije. Prikupljeni „sirovi“ slikovni podaci su potom naknadno procesirani u postupcima radiometrijske i geometrijske korekcije. Spajanjem pankromatskih i multispektralnih aerosnimaka (eng. *pan-sharpening*) dobivene su ICK aerosnimke. Također, provedena je i aerotriangulacija aerosnimaka, koja je ispitana pomoću 15 kontrolnih točaka.

Zajedno s digitalnim aerosnimkama dostavljeni su i parametri aerotriangulacije (unutarnje, relativne, vanjske, te parametri izjednačenja bloka aerosnimaka).

3D vektorski podaci za izradu DMR-a prikupljeni su stereo fotogrametrijskom izmjerom digitalnih aerosnimaka. Vektorske podatke sačinjavale su lomne linije terena (prijelomnice), linije oblika, markantne točke terena i pravokutne mreže visinskih točaka međusobnog razmaka 25 m.

3.3. Izrada digitalnih modela površine

Cjelokupni postupak izrade DSM-a proveden je na digitalnoj fotogrametrijskoj stanici korištenjem digitalnog fotogrametrijskog sustava PHOTOMOD 5.24 (Racurs Co., Moskva, Rusija). Konfiguracija hardverskih komponenti digitalne fotogrametrijske stanice prikazana je u radu Balenović i dr. (2015). PHOTOMOD 5.24 je modularni sustav, tj. sastoji se od niza modula koji omogućuju izvođenje raznih fotogrametrijskih postupaka.

Prije same izrade DSM-ova provedeni su postupci pripreme i orijentacije (aerotriangulacije) aerosnimaka. Priprema aerosnimaka za fotogrametrijsko procesiranje koja obuhvaća kreiranje projekta (definiranje projekcije, minimalne i maksimalne nadmorske visine područja) i formiranje bloka aerosnimaka (unos i pozicioniranje aerosnimaka) provedena je u PHOTOMOD Core modulu. Zatim je slijedila orijentacija snimaka odnosno aerotriangulacija koja je provedena postupcima unutarnje, vanjske i relativne orijentacije te izjednačenjem bloka aerosnimaka u PHOTOMOD AT modulu. Parametri unutarnje orijentacije kamere korišteni za aerotriangulaciju su: veličina piksela, žarišna duljina kamere, koordinate glavne točke snimke, te distorzija objektiva, dostupni su u kalibracijskom izvješću kamere. Vanjska orijentacija je provedena unosom parametara zabilježenih tijekom aerosnimanja. Parametri vanjske orijentacije su koordinate projekcijskih središta snimaka (x, y, z) i kutovi rotacije

(ω, ϕ, κ) u trenutku snimanja (ekspozicije). Relativna orijentacija aerosnimaka, odnosno međusobna orijentacija susjednih snimaka bloka provedena je automatskim mjerenjem veznih točaka. Također, kako bi se povećala točnost relativne orijentacije manualno je dodan niz veznih točaka. Naposljetku, izjednačenje bloka aerosnimaka provedeno je metodom zrakovnog snopa (engl. *bundle block adjustment*) u modulu PHOTOMOD Solver. Ulazni elementi za izjednačenje bile su slikovne koordinate svih veznih točaka, parametri unutarnje i vanjske orijentacije.

Za izradu DSM-a korišten je 'Dense DTM' algoritam u modulu PHOTOMOD DTM. Dense DTM je algoritam slikovne korelacije bazirane na plošnim podacima koji radi na način da, primjenom unakrsne korelacije (engl. *cross-correlation*), računa koordinate korespondentnih piksela svih točaka u području preklopa dviju ili više aerosnimaka. Obzirom da se računaju koordinate za svaki piksel, rezolucija tako dobivenog DSM-a odgovara rezoluciji aerosnimaka.

Najprije je izrađen tzv. preliminarni DSM, korištenjem unaprijed zadanih osnovnih i dodatnih postavki (parametara) slikovne korelacije (Balenović i dr. 2015). U postupku slikovne korelacije i izrade DSM-a može doći do pogrešaka (engl. *matching errors*), bilo kao posljedica korištenog algoritma i kvalitete aerosnimaka (St-Onge i dr. 2008) ili karakteristika snimljene površine (Baltsavias i dr. 2008). Kada se radi DSM za šumska područja, pogreške uglavnom nastaju uslijed kompleksne strukture (teksture) šuma, i to ponajprije zbog sjena na aerosnimcima (npr. uz rub šume ili u progalama), strmih nagiba i velikih visinskih razlika (npr. između dva susjedna stabla različitih visina) (St-Onge i dr. 2008, Honkavaara i dr. 2012, Nurminen i dr. 2013, White i dr. 2013). Vizualnom evaluacijom DSM-a utvrđene su pogreške koje se očituju kao 'šiljci' (engl. *spikes*) ili male površine čija je nadmorska visina značajno niža od okoline, te ih je bilo lako uočiti. Za uklanjanje nastalih pogrešaka korišten je PHOTOMOD-ov algoritam 'Filter zgrada i vegetacije' (engl. *Buildings and vegetation filter*), odnosno njegov prvi korak koji se koristi upravo za uklanjanje takvih pogrešaka. Praznine u DSM-u nastale filtriranjem popunjene su interpolacijom (engl. *smooth interpolation method*). Naposljetku, preostale pogreške koje nisu uklonjene primjenom Filtera zgrada i vegetacije izdvojene su manualno te su nastale praznine ponovno popunjene postupkom interpolacije.


Sva tri područja istraživanja su obrađena sa tri rezolucije snimaka - puna, pola i četvrtina rezolucije snimaka (*highest, high i medium*).

Digitalni modeli površina (visina) su rezolucija 30 cm (*highest*), 60 cm (*high*) i 120 cm (*medium*).

4. REZULTATI ISTRAŽIVANJA

Na temelju obrađenih Lidarskih podataka za Park Ribnjak, Trg kralja Petra Svačića, Trg kralja Tomislava dobiveni su slijedeći rezultati;

- Izrađen digitalni model reljefa istraživanog područja (Slika 9.)




Slika 9. DMR parka Ribnjak


- Na temelju aerofotogrametrijskih stereoskopskih snimaka generirani su 3D oblaci točaka različitih rezolucija (srednja, viša i najviša) – slike 10.,11. i 12.



Slika 10. 3D oblaci točaka različitih rezolucija (gustoća) – Trg Petra Svačića




Slika 11. 3D oblaci točaka različitih rezolucija (gustoća) – Ribnjak

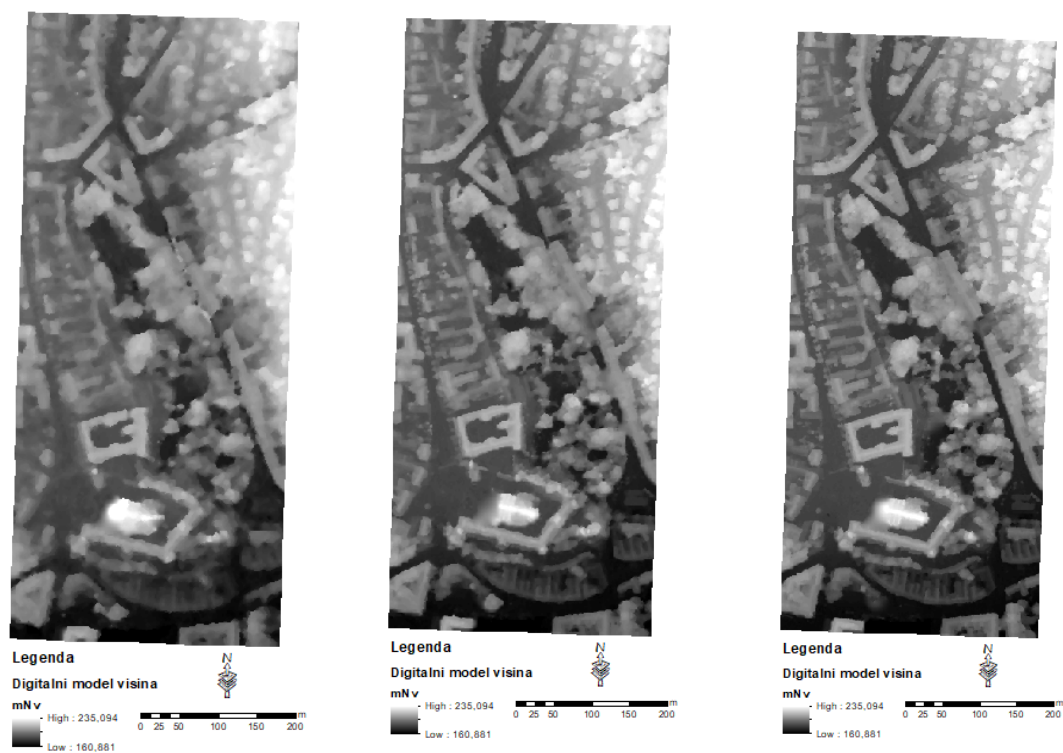


Slika 12. 3D oblaci točaka različitih rezolucija (gustoća) – Trg kralja Tomislava


- Digitalni modeli visina područja istraživanja (različitih rezolucija) – slika 13., 14. i 15.



Slika 13. Digitalni modeli visina područja istraživanja (različitih rezolucija) – Trg Petra Svačića



Slika 14. Digitalni modeli visina područja istraživanja (različitih rezolucija) – Ribnjak




Slika 15. Digitalni modeli visina područja istraživanja (različitih rezolucija) – Trg kralja Tomislava

- Generirani su i klasificirani oblaci točaka područja istraživanja – slike 16. i 17.

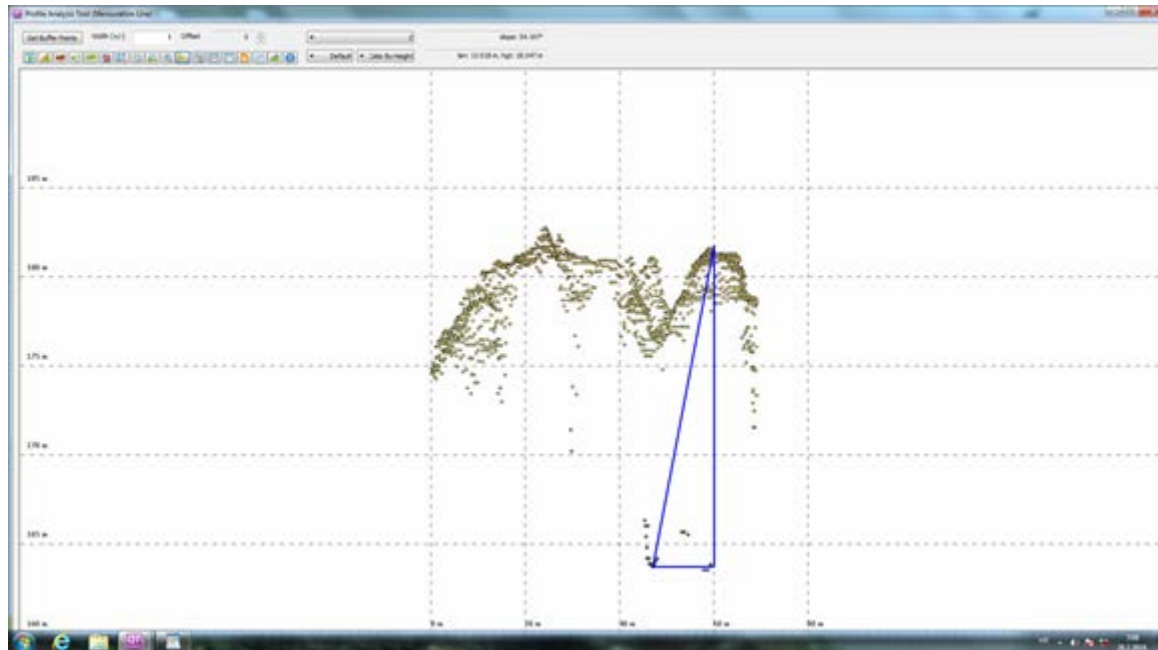


Slika 16. Klasificirani oblaci točaka područja istraživanja – Trg Petra Svačića

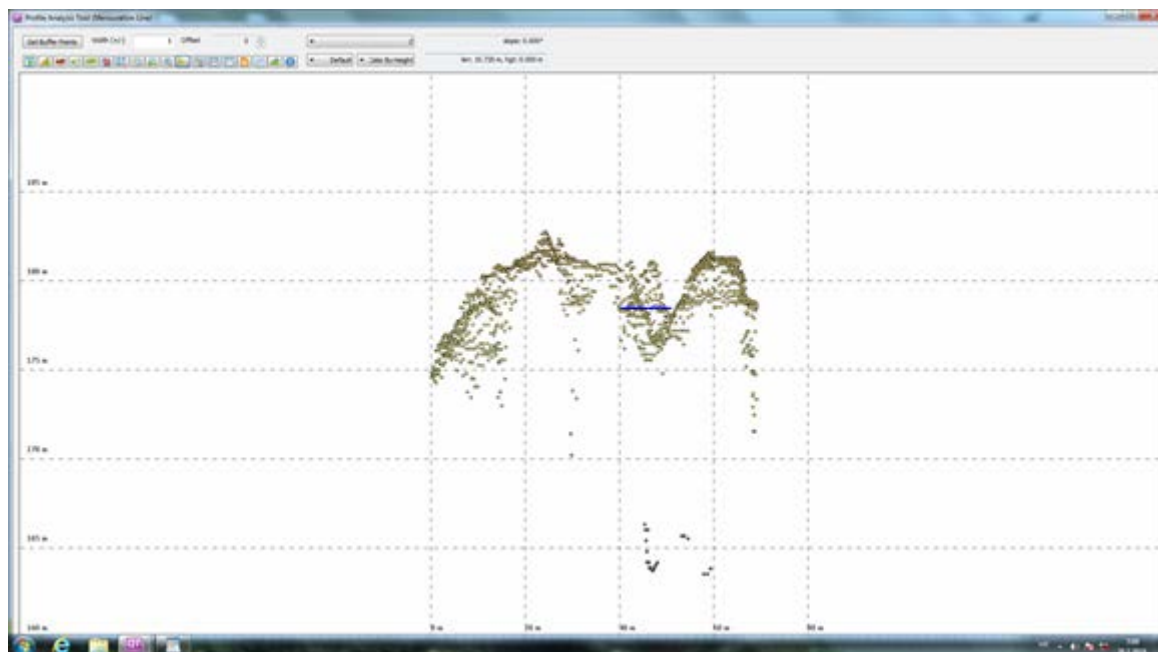


Slika 17. Klasificirani oblaci točaka područja istraživanja – Trg kralja Tomislava

Na temelju izrađenih digitalnih modela terena i digitalnih modela površina (visina) izrađeni su i profili područja od interesa na kojima su izmjerene visine (Slika 18.) pojedinačnih stabala kao i širine krošnje (Slika 19.).



Slika 18. Izmjera visina pojedinačnog stabla



Slika 19. Izmjera širine krošanja

Kao što je vidljivo iz izrađenih profila (Slika 18. i 19.) oblaci točaka dobiveni na temelju aerofotogrametrijskog snimanja pružaju mogućnost izrade profila snimljenog područja, ali samo za gornji sloj vegetacije. Upravo iz tog razloga moguća je izmjera samo gornje etaže unutar neke sklopljene sastojine ili šume, ali za potrebe praćenja stanja stabala i vegetacije urbanih područja daje korisne i vrlo precizne podatke.



Slika 20. Oblak točaka prevučen preko digitalnog ortofota područja istraživanja

5. ZAKLJUČCI

- U diplomskom radu su prikazane mogućnosti primjene 3D podataka iz aerofotogrametrijskog snimanja za potrebe praćenja i inventure urbanih područja.
- Glavni produkti dobiveni aerofotogrametrijskim snimanjem su izrađen DMT - digitalni model terena i DMP – digitalni model površina, koji nam omogućuju na brz i efikasan način prikupljanje podataka o visini, širini krošnje, površini krošnje pojedinačnog stabla.
- Na temelju obrađenih aerofotogrametrijskih snimaka područja istraživanja razvidno je da nam svi dobiveni produkti (3D oblaci točaka, DMT I DMP) omogućuju izmjera samo gornje etaže unutar neke sklopljene sastojine ili šume, ali za potrebe praćenja stanja stabala i vegetacije urbanih područja daje korisne i vrlo precizne podatke.
- Rezultati ovog istraživanja ukazuju na neke od mogućosti upotrebe 3D podataka dobivenih metodama daljinskih istraživanja, te otvaraju nove mogućnosti u analizama i interpretaciji funkcija urbanih šuma i parkova.

6. LITERATURA

1. Anttila, P., 1998: On the accuracy of tree-wise attributes obtained by analytical stereoplotter and aerial images. MSc thesis, University of Joensuu, Faculty of Forestry, Joensuu, 36p.
2. Balenović, I., H. Marjanović, M. Benko, 2010: Primjena aerosnimaka u uređivanju šuma u Hrvatskoj. Šumarski list, 134 (11-12): 623-631.
3. Balenović, I., A. Seletković, R. Pernar, H. Marjanović, D. Vuletić, M. Benko, 2012: Comparison of Classical Terrestrial and Photogrammetric Method in Creating Management Division. Šumarski fakultet Sveučilišta u Zagrebu, 1-13, Zagreb.
4. Balenović, I., H. Marjanović, K. Indir, D. Vuletić, M.Z. Ostrogović, M. Benko, 2013: Estimation of the Stands' Arithmetic Mean Diameter using Manual Method of Digital Photogrammetry. Period. Biol., 115 (3): 399-407.
5. Balenović, I., A. Seletković, R. Pernar, A. Jazbec, 2015: Estimation of the mean tree height of forest stands by photogrammetric measurement using digital aerial images of high spatial resolution. Ann. For. Res., 58 (1): 125-143.
6. Baltsavias, E., A. Gruen, H. Eisenbeiss, L. Zhang, L. T. Waser, 2008: High-quality image matching and automated generation of 3D tree models. International Journal of Remote Sensing, 29(5): 1243–1259.
7. Benko, M., 1993: Procjena taksacijskih elemenata sastojina na infracrvenim kolornim aerosnimkama. Glasnik za šumske pokuse, 29: 199-274.
8. Bohlin, J., J. Wallerman, J. E. S. Fransson, 2012: Forest variable estimation using photogrammetric matching of digital aerial images in combination with a high-resolution DEM. Scandinavian Journal of Forest Research, 27(7): 692–699.
9. Dogon-Yaro, M. A., Kumara, P., Abdul Rahman, A., Buyuksalih, G., 2016: Semi-automated approach for mapping urban trees from integrated aerial LiDAR point cloud and digital imagery datasets. The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, Volume XLII-4/W1, 2016 International Conference on Geomatic and Geospatial Technology (GGT) 2016, 3–5 October 2016, Kuala Lumpur, Malaysia. Preuzeto s <<https://www.int-arch-photogramm-remote-sens-spatial-inf-sci.net/XLII-4-W1/127/2016/isprs-archives-XLII-4-W1-127-2016.pdf>>. Pristupljeno: 28. travnja 2018.

10. Eid, T., Gobakken, T., Næsset, E., 2004: Comparing stand inventories for large areas based on photo-interpretation and laserscanning by means of cost-plus-loss analyses. *Scandinavian Journal of Forest Research*, 19(6): 512-523.
11. Ginzler, C., M.L. Hobi, 2015: Countrywide Stereo-Image Matching for Updating Digital Surface Models in the Framework of the Swiss National Forest Inventory. *Remote Sens.*, 2015, 7 (4): 4343-4370.
12. Gobakken, T., O. M. Bollandsås, E. Næsset, 2015: Comparing biophysical forest characteristics estimated from photogrammetric matching of aerial images and airborne laser scanning data. *Scandinavian Journal of Forest Research*, 30(1): 73–86.
13. Gong, P., Y. Sheng, G.S. Blasing, 2002: 3D Model-Based Tree Measurement from High-Resolution Aerial Imagery. *Photogramm. Eng. Rem. S.*, 68 (11): 1203-1212.
14. Granholm, A. E., A. Olsson, M. Nilsson, A. Allard, J. Holmgren, 2015: The potential of digital surface models based on aerial images for automated vegetation mapping. *International Journal of Remote Sensing*, 36(7): 1855–1870.
15. Gruber M., M. Ponticellia, S. Bernögger, F. Leberl, 2008: Ultracamx, the Large Format Digital Aerial Camera System by Vexcel Imaging/Microsoft. U: Proceedings of ISPRS XXIst Congress ‘Silk Road for Information from Imagery’, Vol. XXXVII, Part B1, 665-670, Beijing.
16. Hobi, M. L., C. Ginzler, 2012: Accuracy Assessment of Digital Surface Models Based on WorldView-2 and ADS80 Stereo Remote Sensing Data. *Sensors*, 12(5): 6347–6368.
17. Honkavaara, E., L. Markelin, T. Rosnell, K. Nurminen, 2012: Influence of solar elevation in radiometric and geometric performance of multispectral photogrammetry. *ISPRS Journal of Photogrammetry and Remote Sensing*, 67: 13–26.
18. Höhle, J., M. Höhle, 2009: Accuracy assessment of digital elevation models by means of robust statistical methods. *ISPRS Journal of Photogrammetry and Remote Sensing*, 64(4): 398–406.
19. Järndstedt, J., A. Pekkarinen, S. Tuominen, C. Ginzler, M. Holopainen, R. Viitala, 2012: Forest variable estimation using a high-resolution digital surface model. *ISPRS Journal of Photogrammetry and Remote Sensing*, 74: 78–84.
20. Kolić, J., R. Pernar, A. Seletković, M. Ančić, 2015: The Importance of CIR Aerial Imagery in Inventory, Monitoring and Predicting Forest Condition. *South-east Eur. for.*, 6 (2): 191-200.

21. Korpela, I., 2004: Individual tree measurements by means of digital aerial photogrammetry. *Silva Fenn. monogr.*, 3: 1-93.
22. Kovats, M., 1997: A large-scale aerial photographic technique for measuring tree heights on long-term forest installations. *Photogrammetric Engineering and Remote Sensing*, 63(6): 741-747.
23. Kušan, V., 1992: Procjena volumena sastojina četinjača fotointerpretacijom aerosnimaka uz pomoć prirasno-prihodnih tablica. *Meh. šumar.*, 17 (3-4): 53-66.
24. Kušan, V., 1996: Pristup daljinskim istraživanjima i GIS-u u hrvatskome šumarstvu. *Šumarski list*, 3-4, str. 171.
25. Leberl, F., A. Irschara, T. Pock, P. Meixner, M. Gruber, S. Scholz, A. Wiechert, 2010: Point Clouds: Lidar versus 3D Vision. *Photogrammetric Engineering & Remote Sensing*, 76(10): 1123–1134.
26. Linder, W., 2009: Digital photogrammetry – A practical course. Springer, 220 str., Berlin.
27. Magnusson, M., Fransson, J.E.S., 2005: Evaluation of aerial photo-interpretation for estimation of forest stem volume at stand level. Swedish Forest Agency, Report 8, Vol C, pp. 102-106.
28. Magnusson, M., J.E.S. Fransson, H. Olsson, 2007: Aerial photointerpretation using Z/I DMC images for estimation of forest variables. *Scandinavian Journal of Forest Research*, 22 (3): 254-266.
29. Næsset, E., 1996: Determination of number of stems in coniferous forest stands by means of aerial photo-interpretation. *Scandinavian Journal of Forest Research*, 11(1): 76-84.
30. Næsset, E., 2002: Determination of mean tree height of forest stands by means of digital photogrammetry. *Scandinavian Journal of Forest Research*, 17 (5): 446-459.
31. Nurminen, K., M. Karjalainen, X. Yu, J. Hyypä, E. Honkavaara, 2013: Performance of dense digital surface models based on image matching in the estimation of plot-level forest variables. *ISPRS Journal of Photogrammetry and Remote Sensing*, 83: 104–115.
32. Ota, T., M. Ogawa, K. Shimizu, T. Kajisa, N. Mizoue, S. Yoshida, G. Takao, Y. Hirata, N. Furuya, T. Sano, H. Sokh, V. Ma, E. Ito, J. Toriyama, Y. Monda, H. Saito, Y. Kiyono, S. Chann, N. Ket, 2015: Aboveground Biomass Estimation Using Structure from Motion Approach with Aerial Photographs in a Seasonal Tropical Forest. *Forests*, 6 (11): 3882-3898.

33. Paparoditis, N., L. Polidori, 2002: Overview of digital surface models. Digital photogrammetry (U: Egels, Y., M. Kasser), Taylor and Francis, London, New York, 159–163.
34. Petrie G., A. S. Walker, 2007: Airborne Digital Imaging Technology: a New Overview. Photogramm. Rec., 22 (119): 203-225.
35. Pitt, D. G., M. Woods, M. Penner, 2014: A Comparison of Point Clouds Derived from Stereo Imagery and Airborne Laser Scanning for the Area-Based Estimation of Forest Inventory Attributes in Boreal Ontario. Canadian Journal of Remote Sensing, 40(3): 214–232.
36. Puliti, S., T. Gobakken, H. O. Ørka, E. Næsset, 2016: Assessing 3D point clouds from aerial photographs for species– specific forest inventories. Scandinavian Journal of Forest Research, 32(1): 68-79.
37. Rahlf, J., J. Breidenbach, S. Solberg, R. Astrup, 2015: Forest Parameter Prediction Using an Image-Based Point Cloud: A Comparison of Semi-ITC with ABA. Forests, 6(11): 4059– 4071.
38. Sandau, R., 2010: Digital Airborne Camera, Introduction and Technology. Springer, 343 str., Dordrecht.
39. St-Onge, B., C. Véga, R.A. Fournier, Y. Hu, 2008: Mapping canopy height using a combination of digital stereo-photogrammetry and lidar. International Journal of Remote Sensing, 29(11): 3343–3364.
40. St-Onge, B., F. A. Audet, J. Bégin, 2015: Characterizing the Height Structure and Composition of a Boreal Forest Using an Individual Tree Crown Approach Applied to Photogrammetric Point Clouds. Forests, 6(11): 3899–3922.
41. Ståhl, G., 1992: A study on the quality of compartmentwise forest data acquired by subjective inventory methods (Report 24). Umeå: Department of Biometry and Forest Management, Swedish University of Agricultural Sciences.
42. Straub, C., C. Stepper, R. Seitz, L. T. Waser, 2013: Potential of UltraCamX stereo images for estimating timber volume and basal area at the plot level in mixed European forests. Canadian Journal of Forest Research, 43(8): 731–741.
43. Stepper, S., C. Straub, H. Pretzsch, 2015: Assessing height changes in a highly structured forest using regularly acquired aerial image data. Forestry, 88(3): 304–316.

44. Smits, I., G. Frieditis, S. Dagis, D. Dubrovskis, 2012: Individual tree identification using different LIDAR and optical imagery data processing methods. *Biosystems and Information Technology*, 1 (1): 19-24.
45. Tanhuanpää, T., N. Saarinen, V. Kankare, K. Nurminen, M. Vastaranta, E. Honkavaara, M. Karjalainen, X. Yu, M. Holopainen, J. Hyypä, 2016: Evaluating the Performance of High-Altitude Aerial Image-Based Digital Surface Models in Detecting Individual Tree Crowns in Mature Boreal Forests. *Forests*, 7(7): 143.
46. Tuominen, S., J. Pitkänen, A. Balazs, K.T. Korhonen, P. Hyvönen, E. Muinonen, 2014: NFI plots as complementary reference data in forest inventory based on airborne laser scanning and aerial photography in Finland. *Silva Fenn.*, 48 (2): article id 983.
47. Zavod za fotogrametriju (2018) Fotogrametrija i daljinska istraživanja. Preuzeto s: <http://www.zzf.hr/index.php/o-nama/ekipe/fotogrametrija-i-daljinska-istrazivanja>. Pristupljeno 2. svibnja 2018.
48. White, J. C., M. A. Wulder, M. Vastaranta, N. C. Coops, D. Pitt, M. Woods, 2013: The utility of image-based point clouds for forest inventory: A comparison with airborne laser scanning. *Forests*, 4(3): 518–536.
49. White, J.C., C. Stepper, P. Tompalski, N.C. Coops, M.A. Wulder, 2015: Comparing ALS and Image-Based Point Cloud Metrics and Modelled Forest Inventory Attributes in a Complex Coastal Forest Environment. *Forests*, 6 (10): 3704-3732.
50. Yu, X., J. Hyypä, M. Karjalainen, K. Nurminen, K. Karila, M. Vastaranta, V. Kankare, H. Kaartinen, M. Holopainen, E. Honkavaara, A. Kukko, A. Jaakkola, X. Liang, Y. Wang, H. Hyypä, M. Katoh, 2015: Comparison of Laser and Stereo Optical, SAR and InSAR Point Clouds from Air- and Space-Borne Sources in the Retrieval of Forest Inventory Attributes. *Remote Sens.*, 7 (12): 15933-15954.